

# EBP와 OVSSA의 특성을 이용하는 분류 알고리즘

이종찬  
청운대학교 인터넷학과

## Classification algorithm using characteristics of EBP and OVSSA

Jong Chan Lee  
Dept. of Internet, Chungwoon University

요 약 본 논문은 다층을 갖는 네트워크를 가장 효율적으로 학습하는 것은 결국 최적의 가중치 벡터의 집합을 찾아가는 과정이라는 간단한 접근 방법을 기본으로 하고 있다. 일반적인 학습 문제의 단점을 극복하기 위해 제안 모델에서는 EBP와 OVSSA의 특징들을 결합한 방법을 사용한다. 즉 EBP가 지역 최소치에 빠질 수 있는 성질을 보강하기 위해 OVSSA의 확률 이론으로 빠져나갈 수 있도록 제안 방법은 각각 알고리즘의 장점만을 취하여 하나의 모델을 구성한다. 제안 알고리즘에서는 EBP에서 오류를 줄이기 위한 방법들을 에너지함수로 사용하고, 이 에너지를 OVSSA로 최소화 하는 방법을 사용하였다. 두 가지의 상이한 성질을 가지는 알고리즘이 합쳐질 수 있음을 간단한 실험 결과를 통해 확인한다.

주제어 : 오류역전과 알고리즘, OVSSA, 분류, 에너지 함수, 최적화 문제

**Abstract** This paper is based on a simple approach that the most efficient learning of a multi-layered network is the process of finding the optimal set of weight vectors. To overcome the disadvantages of general learning problems, the proposed model uses a combination of features of EBP and OVSSA. In other words, the proposed method can construct a single model by taking advantage of each algorithm so that it can escape to the probability theory of OVSSA in order to reinforce the property that EBP falls into local minimum value. In the proposed algorithm, methods for reducing errors in EBP are used as energy functions and the energy is minimized to OVSSA. A simple experimental result confirms that two algorithms with different properties can be combined.

**Key Words** : EBP, OVSSA, Classification, Energy function, Optimization problem

### 1. 서론

EBP 알고리즘으로 다층을 가지는 네트워크를 학습할 수 있음이 밝혀지면서 여러 응용 분야에 적용되어 좋은 결과를 보여 왔다[1,2]. 여러 연구자 들은 네트워크 구조가 문제에 따라 변경되며, 출력 노드들의 값이 0과 1사이 라는 특성에 따라 3층 이상이 되는 경우 학습이 어렵다는 점을 지적해 왔다. 이 문제를 해결하는 방안으로 시그모이드 함수 대신에 LeRU와 같은 함수로 대체하면서 Deep Learning으로 발전[3-5]했으며, 요즘 많은 각광을 받고 있다[6,7]. 그러나 여전히 다음과 같은 문제들이 해결해야 할 문제로 알려져 있다.

우선 각 층의 노드 갯수가  $N_0, N_1, N_2, N_4$ 개라 할 때 학습을 위해  $O(N_0, N_1, N_2, N_4)$ 의 가중치를 학습시켜야 한다[8]. 따라서 학습하는데 엄청난 시간이 필요하다. 또한 EBP는 오류를 줄이는 방법으로 일반화된 점진 강화 기법을 사용하기 때문에 많은 문제에서 지역 최소치에 빠지기 쉽고 이 경우 빠져 나오는 방법이 없다.

이러한 문제를 해결하기 위해 여러 모델들이 소개되었는데 그 중에서 정홍[9,10]은 EBP가 지역 최소치에 빠지는 성질과 SA이 전역 연산(global computation)을 해야 하는 각 알고리즘의 구조적 문제를 제기하고, EBP에서 지역 연산, SA에서 전역 최소치에 수렴할 확률이 높

\*Corresponding Author : Jong Chan Lee(jclee@chungwoon.ac.kr)

Received December 13, 2017

Accepted February 20, 2018

Revised December 17, 2017

Published February 28, 2018

다는 점을 고려해 각각 알고리즘의 장점만을 취해 하나의 모델을 구성함으로써 해결하려 하였다. 그는 또한 EBP 알고리즘에서 오류를 줄이기 위한 방법들을 에너지 함수로 사용하였으며, 입력을 출력으로 복사하는 간단한 실험을 하였다.

SA 알고리즘은 온도의 scheduling 문제에 민감하고 수렴 속도가 느리다고 알려져 있다. 따라서 본 논문에서는 SA의 한 단계 발전된 알고리즘인 OVSSA[11-13]를 사용한다. SA와 OVSSA는 Monte Carlo 기법을 기반으로 하는 Metropolis 알고리즘을 사용한다는 점은 유사하다. 즉 상태천이를 하여 전 상태와 다음 상태의 에너지 차이를 구하고 이 차이가 0보다 작으면(좋은 상태) 받아들이고 0보다 큰 경우(나쁜 상태)라 하더라도 Boltzmann 확률을 가지고 새로운 상태를 받아들인다는 것이다. 그러나 SA는 전체 노드를 한꺼번에 상태천이 하는데 반해 OVSSA는 하나의 노드만 상태천이를 한 후 에너지를 구하는 점이 다르다. 이 다른 점이 SA와는 다르게 병렬로 수행할 수 있는 장점이 있다.

또한 본 논문은 EBP의 문제를 해결하기 위해, 층 별로 병렬 학습을 할 수 있는 모델을 개발하여 시간의 문제에 대해 접근하고, 일반화된 점진 강화 기법이 아닌 확률적 기법을 적용한 OVSSA 알고리즘을 적용해 지역 최소치에 빠지는 확률을 줄일 수 있도록 알고리즘을 구성한다.

## 2. 학습 알고리즘

### 2.1 오류역전과 알고리즘

전형적인 EBP 네트워크는 입력층, 은닉층, 출력층으로 구성되며, 은닉층과 출력층의 모든 노드들은 편기(bias) 노드를 가지고 있다. 그리고 현재층과 상위층 사이의 각 노드들은 노드들 사이의 연관 강도를 나타내는 가중치(weight)를 가지며 모두 연결(full-connect)되어 있다.

이 네트워크의 학습 과정은 전향 단계와 후향 단계로 나누어진다. 패턴을 제시하고 각 뉴런에 대해 망입력함수( $net_i$ )와 활성화 함수를 이용하여 출력( $O_i$ )을 산출하는 것이 전향(forward)단계이고, 후향(backward) 단계는 기대출력값과 실제출력값 간의 오차를 구한 후, 이 차이를 역전과 시키면서 층과 층 사이의 가중치를 조절한다. 이 두가지 과정은 미리 정해진 수치만큼 안정될 때까지 즉,

총 오류합을 오류 기준치(error criterion)와 비교해 가며 같은 과정을 계속 반복 실행한다. 이들 단계를 구체적으로 살펴보면 한 패턴을 위한 전향단계는 (1)식과 같이 수행된다.

$$\text{입력값} : net_{p_j} = \sum_i W_{ji} O_{p_i} + \theta_j \quad (1)$$

$$\text{출력값} : O_{p_j} = f_j(net_{p_j})$$

여기서 임계값과 반대 부호를 갖는  $\theta$ 는 편기로 항상 1 값을 갖고,  $f(\cdot)$ 는 시그모이드 함수를 나타낸다. 전향 단계의 마지막에서 (2)식과 같은 MSE(mean square error) 오류 값을 구한다.

$$E_p = \frac{1}{2} \sum_j (t_{p_j} - O_{p_j})^2 \quad (2)$$

또한 패턴 전체에 대한 총 오류는 (3)식과 같다.

$$E = \sum_p E_p \quad (3)$$

이 오류를 최소화하기 위해 후향 단계에서는 (4)식과 같은 일반화된 델타를 사용한다.

$$\begin{aligned} \frac{\partial E_p}{\partial W_{ji}} &= \frac{\partial E_p}{\partial net_{p_j}} \frac{\partial net_{p_j}}{\partial W_{ji}} \\ &= \delta_{p_j} O_{p_i} \end{aligned} \quad (4)$$

$$\begin{aligned} \delta_{p_j} &= - \sum_k \frac{\partial E_p}{\partial O_{p_k}} \frac{\partial O_{p_k}}{\partial net_{p_j}} \\ &= - \frac{\partial E_p}{\partial O_{p_j}} f'_j(net_{p_j}) \end{aligned}$$

출력층에서  $\delta_{p_j}$ 는 (5)식과 같이 구해진다.

$$\delta_{p_j} = (t_{p_j} - O_{p_j}) f'_j(net_{p_j}) \quad (5)$$

또한 은닉층에서  $\delta_{p_j}$ 는 (6)식과 같이 구해진다. 각 노드에서 오류 값이 계산된 후에 (7)식과 같은 연결 가중치가

점진적으로 변경되며 학습이 이루어진다.

$$\begin{aligned} \frac{\partial E_p}{\partial O_{p_j}} &= \sum_k \frac{\partial E_p}{\partial net_{p_k}} \frac{\partial net_{p_k}}{\partial O_{p_j}} \quad (6) \\ &= \sum_k \frac{\partial E_p}{\partial net_{p_k}} \frac{\partial}{\partial O_{p_j}} (\sum W_{ki} O_{p_i}) \\ &= \sum_k \frac{\partial E_p}{\partial net_{p_k}} W_{kj} \\ &= -\sum_k \delta_{p_k} W_{kj} \end{aligned}$$

$$\delta_{p_j} = \sum_k \delta_{p_k} W_{kj} f'(net_{p_j})$$

$$\Delta_p W_{ji}(n+1) = \eta(\delta_{p_j} O_{p_i}) + \alpha \Delta_p W_{ji}(n) \quad (7)$$

여기서  $\eta$ 는 학습율(learning rate)을,  $\alpha$ 는 모멘텀(momentum)이다.

이와 같은 전향과 후향 단계를 네트워크가 충분히 학습될 때까지 반복한다.

## 2.2 OVSSA

SA는 고체 물리학에서 높은 온도에서 낮은 온도로 서서히 변경해 가며 에너지를 최소화하는 방향으로 시스템을 재배치하는 과정을 알고리즘화한 것이다. 이 알고리즘은 지역최소치에서 확률적으로 벌어지는 과정을 반복하여 전역최소치를 구해간다. 이를 통해 많은 시간을 요하는 실전 문제에서 효과적인 해답을 얻어냈다고 보고되고 있다.

MFA 알고리즘은 SA와 홉필드 모델의 특성을 결합한 모델이다. 이 모델은 조합 최적화 문제인 NP-complete 문제에 적용하여 좋은 해를 구해왔다. 이와 같은 결과는 평균장 근사 기법으로 각 변수의 값을 대체해 가는 방법을 사용함으로써 가능하다는 것이 밝혀졌다. MFA는 본래 이산 값이나 이진 값만을 처리할 수 있는 알고리즘으로 연속값을 가지는 응용문제에는 적용할 수 없었다. 이러한 점은 각 변수의 평균값을 결정해야 하는 문제에 적용하기 어려운 문제를 가지고 있었다. 이 문제를 해결하고자 MFA를 변형한 OVSSA를 가지고 TSP, 퍼지 집합분석, VLSI 디자인, 정량화 분석 문제 등이 여러 실전 문제[14,15]에 적용하여 좋은 결과를 산출하였다. OVSSA는 SA에서 이용하는 전이 확률을

상태전이(perturb)된 특정 스핀 값의 평균을 구하는 방법을 사용한다. 이것은 Markov 처리과정을 통해 스핀 평균  $\langle S_i \rangle$ 를 근사적으로 계산하고, 평균장하에서 많은 샘플링을 가능하게 한다. 그러므로 모든 노드가 병렬로 처리할 수 있게 하고, 연속 값을 가지는 시스템에서 전역 최소치를 얻을 수 있게 한다. 너무 많은 노드를 가지는 실전 문제에서 OVSSA를 적용하기 위한 연속 값을 가지는 함수로 근사해를 구할 수 있도록 한다. 이 알고리즘은 SA 알고리즘과 유사하다. 그러나 SA는 모든 스핀이 열 균형 상태를 위해 상태천이하나, OVSSA는 임의로 선택된 하나의 스핀만이 상태천이하고 다른 스핀들의 평균장하에서 변경된다. 그러므로 이 과정은 모든 스핀들에 병렬로 적용할 수 있다. OVSSA에서 스핀들의 평균을 구하는 과정은 다음과 같다.

Step 1 : 하나의 변수  $s$ 를 임의로 정하고 이 변수를 상태천이 하여 새로운  $s'$ 를 구한다.

Step 2 : 비용  $E(s')$ 를 계산하고 이전의 비용  $E(s)$ 와의 차이를 계산하여 변수  $s$ 가 다음과 같은 확률로 상태천이된  $s'$ 의 값을 받아들이도록 한다.

$$\begin{aligned} \Pr(s' \leftarrow s) &= 1 && \text{if } E(s') < E(s) \\ &= \exp^{-E(s')-E(s)/T} && \text{if } E(s') \geq E(s) \end{aligned}$$

Step 3 : Step 1과 Step 2를 여러 번 반복한다.

Step 4 : Step 1에서 Step 3의 과정에서 받아들인 상태 값들만의 평균을 구하고 이것을 주어진 온도 (T)에서 변수의 평형상태 평균으로 간주한다.

## 3. 제안 알고리즘

### 3.1 에너지 함수

최적화 문제에서 가장 어려운 것은 주어진 문제의 에너지를 최소화 할 수 있도록 하는 에너지 함수를 정하는 것이다[14,15]. 다시 말해 최적의 가중치를 찾아가도록 하는 내용이 포함되어야 한다. 본 모델에서 최적의 가중치라 함은 오류를 최소로 하는 집합을 말한다.

전체 시스템의 오류를 최소로 하기 위해서는 전체 시스템을 구성하는 각 층에서 각 노드들의 오류를 최소화 해야 한다. EBP의 네트워크 구조는 입력층, 은닉층, 출력층으로 구성되어 있다. 여기서 EBP가 지도학습을 하기 때문에 출력층에서의 노드  $i$ 의 오류는  $t_i - O_i$ 와 같이 쉽

계 구할 수 있다. 그러나 은닉층과 입력층의 노드의 경우는 오류를 직접적으로 측정할 수 없다는 것이 문제이다. 이것은 기대되는 출력값( $t$ )이 출력층의 노드에만 연결되어 있고 그 외의 층에서는 학습하는 도중에  $t$ 값을 알 수 없기 때문이다. 그러나 EBP는 학습하는 도중에 출력층의 가중치 뿐만 아니라 입력층, 은닉층의 가중치들도 오류를 줄이는 방향으로 수렴해 간다. 이것은 출력층 이외의 노드들에서도 가상적인  $t$ 값을 적용하고 이 값에 상응하는 출력 오류를 최소화하는 것 이라고 볼 수 있다. 따라서 EBP 알고리즘 내에 은닉층 및 입력층을 학습하는 부분에서 문제의 해답을 얻을 수 있을 것이다.

EBP 알고리즘에서 출력층의 노드  $i$ 에 대한  $\delta_i$ 는 (5)식과 같이 구하였고 입력 및 은닉층에 대한  $\delta_i$ 는 (6)식과 같이 구했다. 이  $\delta_i$ 을 이용해 (7)식과 같이 가중치의 변화량을 구했다. 여기서 (5)식과 (6)식을 비교해 보면 (5)식의  $t_i - O_i$ 는 (6)식의  $\sum_j \delta_j w_{ji}$ 에 해당되는 것을 알 수 있다.

이에 따라 다음과 같이 오류를 정의한다.

(a)  $i$ 가 출력노드일 때

$$E_i = t_i - O_i$$

(b)  $i$ 가 입력/은닉 노드일 때

$$E_i \cong \sum_j \delta_j w_{ji}$$

위 식에서 (a)은 기대되는 출력값과 실제 학습 중에 계산된 출력값 간의 차이로 명백한 오류값이다. (b)는 은닉노드, 입력노드의 출력값과 가상적인 기대값 간의 차이를 나타낸 값이다. 즉 이 값은 은닉노드, 입력노드에서 오류를 계산하기 위한 추정값이다. 다행히도 (b)의 값은 (6)식에서 설명한 바와 같이 출력층의 오류로부터 간접적으로 구할 수 있다.

이제 네트워크의 각 층에 대해 오류를 구할 수 있으므로 이 오류를 줄이기 위한 에너지 함수를 다음과 같이 정의 한다.

$$\begin{aligned} PSS_{p_i} &= (t_{p_i} - O_{p_i})^2, \text{ 출력층} \\ PSS_{p_i} &= \left( \sum_j \delta_{p_j} w_{p_i} \right)^2, \text{ 입력층, 은닉층} \\ E &= \sum_p \sum_i PSS_{p_i} \end{aligned}$$

### 3.2 학습

$k$ 번째 층의 노드수가  $i$ 개이고  $k+1$ 번째 층의 노드수가  $j$ 개라 할 때  $k$ 번째 층과 다음 층( $k+1$ ) 사이를 연결하는 가중치는  $((i+1) \times j)$  개이다. 이들 중 하나의 가중치를 임의로 선택해 정해진 범위 내에서 상태천이하고 OVSSA의 알고리즘에 따라 이 상태천이된 값을 새로운 가중치로 받아들일 것인가를 결정하는 과정을 여러 번 반복한다. 그 다음  $k+1$  층과  $k+2$  층 사이의 가중치에 대해서도 똑같은 과정을 반복한다.

이 과정을 다시 설명하면 첫째 하나의 가중치를 골라 상태천이하고 EBP와 같이 (1), (2)식을 사용해서 전향단계를 수행한다. 그 다음 후향단계로 각 노드의 오류를 계산하는 에너지를 알아본다. 이 에너지를 학습 패턴 각각에 대해 누적하고 이 값을 OVSSA 알고리즘의 입력으로 하여 이 가중치를 새로운 가중치로 받아들이느냐 그렇지 않느냐를 결정한다. 이들 과정들을 알고리즘으로 표현하면 다음과 같다.

#### 1. 초기화 과정

$T$  = 시작 온도( $T_0$ ), 최종 온도( $T_f$ )

$w_{ij}$  =  $[-1, 1]$  범위에서 임의수 할당

$B$  = 초기 상태천이 범위를  $[-0.1, 0.1]$ 로 정한다

#### 2. 적응 과정

WHILE( $T < T_f$ )

임의로  $\delta w_{ij}$  선택

LOOP fixed point에 도달될 때까지

범위  $B$ 안에서  $\delta w_{ij}$ 를 상태천이

$$w'_{ij} = w_{ij} + \delta w_{ij}$$

$$\Delta E = E(w'_{ij}) - E(w_{ij})$$

IF( $\Delta E < 0$ ) THEN accept  $\delta w_{ij}$

ELSEIF( $\exp(-\Delta/T) > \text{random}[0,1]$ ) THEN accept  $\delta w_{ij}$

ELSE reject  $\delta w_{ij}$

ENDLOOP

Accept된  $w_{ij}$  값들의 평균값으로  $w_{ij}$  값을 정함.

$$T = \lambda \times T$$

$$B = \beta \times B$$

ENDWHILE

여기서  $\lambda$ 는 온도감소율이고  $\beta$ 는 상태전이 범위감소율을 말한다.

#### 4. 실험

SA, OVSSA 등의 최적화 알고리즘에서는 초기온도 ( $T_0$ )를 결정하는 것이 전체 성능에 커다란 영향을 미칠 수 있다. 실험에서는 적절하게 정해진 횟수만큼 초기 범위 내에서 상태전이를 한 후, 이들의 에너지 평균을 구한다. 이 값의 10배 정도이면 초기 온도로 적당하다.

제안 모델에서 최적화 알고리즘으로 이용하고 있는 OVSSA는 임의수를 사용하는데 이를 생성하기 위한 범위를 정하는 문제도 중요한 문제이다. 매우 큰 범위를 갖는 학습에서는 어떠한 경우에는 빠르게 수렴하는 경우도 있으나 일반적인 경우에는 수렴하는 것을 어렵게 한다고 알려져 있다. 실험에서는  $[-1,1]$ 과  $[-0.1,0.1]$ 사이의 여러 경우에 대해 실험했는데 작은 범위를 가지는 것이 보다 좋은 결과를 나타내었다.

온도 감소율( $\lambda$ )과 범위 감소율( $\beta$ )도 시스템의 성능을 좌우하는 중요한 요소이다. 특히 온도가 학습에 매우 민감한데 온도를 급속히 낮출 경우 수렴이 잘 안되는 경향이 있다. 반면 너무 천천히 낮출 경우 수렴속도가 너무 느리게 된다. 본 실험에서는 간단히 EX-OR, 패리티 문제를 실험하였고, 복잡한 데이터로 10개의 모음을 대상으로 발음하여 수집한 Peterson & Barney 데이터를 사용하였다. 실험한 결과 온도 감소율은 0.9, 범위 감소율은 0.98에서 가장 좋은 결과를 보였다. 또한 최종 온도는  $1.154201e-10$ 까지 충분히 떨어지는 것을 확인하였다. 이에 대한 결과는 Table 1과 Table 2에 나타나 있다. 이 결과에서 알 수 있듯이 남성의 경우는 높은 율로 인식되었으나 여성과 어린이의 경우 서로 유사한 경우가 많은 것으로 나타났다. 이로 인해 학습 중에 서로 영향을 미쳐 명확하게 인식하지 못하는 오 분류의 원인이 되어 비교적 낮은 인식률을 보이고 있다. 이는 일반적인 직관과 통하는 결과라고 볼 수 있다.

Table 1. The results of proposed system

Class	Male	Female	Children	Correct (%)
Male	235	3	0	98.74
Female	4	173	24	86.07
Children	0	29	81	73.64

Table 2. The results of SAS

Class	Male	Female	Children	Correct (%)
Male	234	4	0	98.32
Female	6	166	29	82.59
Children	0	21	89	80.91

#### 5. 결론

본 논문에서는 지금까지 OVSSA와 EBP의 장점을 결합하기 위한 알고리즘을 소개하고 실험 결과를 보였다. 이 알고리즘은 타당성 정도를 실험한 단계이고 앞으로 개선할 점들을 많이 가지고 있다. 실제 생물체가 EBP와 같은 학습을 한다면 뉴런이 역방향으로도 연결되어 있어야 하고, 활성화 함수에서의 미분 가능한 기능이 있어야 하기 때문에 실제 생물체의 학습 모델과 가깝다고 보기는 어렵다. 따라서 학습 알고리즘의 연구와 함께 항상 뒤 따라야 하는 것이 네트워크 구조 및 학습 환경에 관한 것이다. 이러한 학습 환경에 따라 시스템의 결과가 크게 좌우되기 때문이다.

신경회로망을 연구하는 많은 연구자들이 여러 가지 응용문제 들을 해결하기 위해 문제마다의 각각의 모델을 개발하였으나, 모든 문제에 적용될 수 있는 일반화된 알고리즘은 아직 개발되고 있지 않다. 이는 자연계에 존재하는 많은 문제들이 지금까지 개발된 많은 모델들 보다 복잡하기 때문이다. 따라서 이들 모델들을 합치고 개선해 나가는 연구가 활발히 이루어져야 한다고 본다.

#### REFERENCES

- [1] D. E. Rumelhart, G. E. Hinton & R. J. Williams (1986), Learning internal representations by error propagation, *PDP, I*, 318-362.
- [2] P. D. Wasserman. (1990), A combined back-propagation / cauchy machine network, *Journal of Neural Network Computing*, 34-40.
- [3] Y. LeCun, Y. Bengio & G. Hinton. (2015, May) ,Deep learning, *Nature*, 521, 436-444.
- [4] G. Hinton & R. Salakhutdinov. (2006, July) Reducing the dimensionality of data with neural networks, *Science*, 313.
- [5] V. Nair & G. E. Hinton. (2010), Rectified linear units improve restricted boltzmann machines, *International*

*Conference on Machine Learning.*

- [6] M. Ranzato, & M. Szummer. (2008), Semi-supervised learning of compact document representations with deep networks. *International Conference on Machine Learning*, 792-799.
- [7] J. Schmidhuber. (2015), Deep learning in neural networks : An overview, *Neural networks*, 1-88.
- [8] J.C.Lee & W.D.Lee. (1994), Pattern classification model based on an optimization tool, *International conference on Neural Information Processing*, 1744-1748.
- [9] H. Jeong. (1988, Oct), Learning scheme for neural networks by simulated annealing with back-propagation, *Workshop for Information Science society, Korean Federation Science and Technology Societies*, 15-20.
- [10] N. Baba & M. Kozaki. (1992, June), An intelligent forecasting system of stock price using neural networks, *IJCNN, I*, 371-377.
- [11] K.Lee, K.Cho, W.Lee & S.Lee. (1992, June), Mean field annealing with continuous variables and its application to the quantification analysis Problem, *IJCNN, II*, 431-435.
- [12] M.Kim, H.Choi & W.D.Lee. (1992, June), Fuzzy clustering using extended MFA for continuous valued state space, *IJCNN, II*, 733-738.
- [13] G. Wang & N. Ansari. (1997), Optimal broadcast scheduling in packet radio networks using mean field annealing, *IEEE Journal on selected areas in communications*, 15(2).
- [14] G. D. Kim & Y. H. Kim. (2017), A survey on oil spill and weather forecast using machine learning based on neural networks and statistical methods, *Journal of the Korea Convergence Society*, 8(10), 1-8.
- [15] Y.D.Yun, Y.W.Yang, H.S.Ji & H.S.Lim. (2017), Development of smart senior classification model based on activity profile using machine learning method, *Journal of the Korea Convergence Society*, 8(1), 25-34.

이 중 찬(Jong Chan Lee)

[중신회원]



인터넷학과 교수

- 1988년 2월 : 충남대학교(학사)
  - 1990년 2월 : 충남대학교 대학원 (석사)
  - 1996년 2월 : 충남대학교 대학원 (박사)
  - 1996년 3월 ~ 현재 : 청운대학교
- 인터넷학과 교수
- 관심분야 : 신경회로망, 패턴분류, 기계학습, 데이터 압축
  - E-Mail : jclee@chungwoon.ac.kr